

PRIMJENA REGULARIZACIJE NA KORELACIJU DIGITALNE SLIKE

Tomičević, Z., Pamuković, F., Surjak, M. & Kodvanj, J.

Sažetak: Korelacija digitalne slike (DIC – Digital Image Correlation) je metoda koja koristi digitalnu sliku za mjerenje cijelog polja pomaka. Svoju primjenu sve više nalazi na polju identifikacije i validacije konstitutivnih zakona. Prednost takve metode neusporediva je sa mjerenjem mehaničkim ekstenzometrima i mjernim trakama koje mjere pomak samo u jednoj točki. Metoda kao takva ima i nedostatak. Prilikom zapisivanja slika javljaju se brze fluktuacije polja pomaka koje su unesene konstantnim šumom kamere te mjernim postavom. Zbog tih problema koristi se regularizacija. U ovom radu prezentirana je primjena nove DIC metode koja koristi regularizaciju (R-DIC) kao sredstvo smanjenja rezolucijske nesigurnosti. Metoda regularizacije služi kao filter za propuštanje samo mehaničkih polja prilikom čega se šum koji se javlja prilikom zapisivanja slika zanemaruje. Prednost regularizacijskog algoritma posebno je vidljiva kada se za analizu koristi siromašna tekstura (niska razina sive skale). Metoda je validirana na umjetno deformiranim slikama, a direktnu primjenu je našla kod biaxialnih testova nodularnog lijeva. Nodularni lijev promatran je na dvije različite skale uvećanja (macro i meso). Za makro razinu korištena je umjetno napravljena tekstura dok je za meso korištena prirodna tekstura nodularnog lijeva.

Ključne riječi: DIC, regularizacija, rezolucija, T3 elementi

1 UVOD

DIC se zasniva na tome da se tijekom provedbe eksperimenta registriraju slike koje imaju sivu razinu skale boja. Zbog brzih fluktuacija uslijed registracije slika koje su također zabilježene potencijalna barijera je jako mala promjena rezolucije pomaka (tj. najmanja promjena mjerenog pomaka koja uzrokuje vidljivu razliku mjerene veličine) koja predstavlja veliki problem prilikom mjerenje malih pomaka. Iz tog razloga potrebno je naći kompromis između standardne mjerne nesigurnosti i rezolucije pomaka [1].

Kako bi se prevladao ovaj limitirajući problem razvijene su različite. Klasična metoda rješavanja ovog problema je diskretizacija polja pomaka na razinu koja je mnogo veća od piksela. Ova metoda je poznatija kao "local DIC approach" [2] gdje je ZOI (zona interesa) definirana kao prirodno pretpostavljena regularizacija. Osim podijele slike na ZOI nikakve druge pretpostvake nisu uvedene, što u konačnici odgovara tome da je cijelo polje pomaka dobiveno interpolacijom centara ZOI. U praksi minimalna veličina ZOI-a je 10x10 piksela ili više [3].

Kako bi se smanjila rezolucija pomaka, neke dodatne informacije mogu biti pretpostavljene. Jedna od njih je da je polje pomaka kontinuirano, a isto se može dekompozirati po odgovarajućoj bazi koja najbolje zadovoljava uvjete kontinuiteta. Problem koji je postojao u lokalnom DIC-u da su sve ZOI tretirane neovisno jedna o

drugoj riješen je ovom metodom koja je poznata kao "global DIC approach" [4]. Ovom metodom vrijeme računanja se povećava ali rezultati su pouzdaniji. Minimalna veličina elementa ove metode je 4x4 piksela [5].

Rezoluciju pomaka moguće je još dodatno smanjiti dodatnim uvjetima kao što su minimiziranje konzervacije sive skale [6]. Problem ove metode je da filter koji je primijenjen može zanemariti fluktuacije koje su nastale uslijed mehaničkih promjena polja pomaka. Drugi način smanjenja rezulocije pomaka biti će predstavljen u ovom radu. Ova metoda zasniva se na mehaničkoj regularizaciji polja pomaka, kojom se filtriraju sve fluktuacije koje nisu mehanički podatljive. Prednost ovakve regularizacije posebno je vidljiva prilikom usporedbe rezolucije pomaka s predstavljenim metodama. U ovom radu tekođer će biti pokazano kako nova metoda može savladati vrlo tešku i nekonvencionalnu teksturu koju klasične DIC metode ne mogu obraditi.

2 REGULARIZIRANA KORELACIJA DIGITALNE SLIKE

2.1 Regularizacijska strategija

Prilikom zabilježavanja dvije slike u referentnoj konfiguraciji, f , te deformiranoj g zbog konzervacije sive skale piksela vrijedi

$$f(\mathbf{x}) = g(\mathbf{x} + \mathbf{u}(\mathbf{x})), \quad (1)$$

gdje je \mathbf{u} nepoznato polje pomaka, a \mathbf{x} lokacija piksela. Traženo polje pomaka minimizira sumu razlike kvadrata Φ_c^2 preko cijelog područja interesa (ROI)

$$\Phi_c^2 = \int_{ROI} \left(|g(\mathbf{x} + \mathbf{u}(\mathbf{x})) - f(\mathbf{x})| \right)^2 d\mathbf{x}. \quad (2)$$

Ako ne postoje neki dodatni uvjeti nemoguće je odrediti pomak svakog piksela nezavisno pošto postoje dvije nepoznanice za danu raliku sive skale. Zbog toga je odabrana slaba formulacija polja pomaka izražena preko odedene baze

$$\mathbf{u}(\mathbf{x}) = \sum_n u_n \psi_n, \quad (3)$$

gdje je ψ_n odabrana funkcija oblika a u_n pripadajući stupnjevi slobode polja pomaka.

Mjereni problem se nadalje sastoji od minimiziranja Φ_c^2 s obzirom na u_n . Newtonov iteracijski algoritam se koristi za rješavanje problema minimiziranja riješavajući iterativno linearni sustav

$$[\mathbf{M}]\{\delta\mathbf{u}\} = \{\mathbf{b}\}. \quad (4)$$

Kako bi se zadovoljila mehanička podatljivost u smislu konačnih elemenata, uvodi se prvo ravnotežna razlika ("equilibrium gap"). Ako je primijenjena linerna elastičnost jednadžbe ravnoteže su

$$[\mathbf{K}]\{\mathbf{u}\} = \{\mathbf{f}\}, \quad (5)$$

gdje je $[\mathbf{K}]$ matrica krutosti, a $\{\mathbf{f}\}$ vektor čvornih sila. U slučaju da polje pomaka ne zadovoljava jednadžbe ravnoteže uvodi se ravnotežna razlika. Uslijed nedostatka čvornih sila, unutrašnji čvorovi su slobodni od svih vanjskih sila, stoga se metoda ravnotežne razlike sastoji od minimiziranja

$$\Phi_m^2 = \{\mathbf{u}\}^t [\mathbf{K}]^t [\mathbf{K}]\{\mathbf{u}\}, \quad (7)$$

gdje je t operator transponiranja, a Φ_m^2 odgovara sumi kvadratne norme svih ravnotežnih razlika ali *samo* unutrašnjih čvorova. Ova DIC metoda zahtijeva dodatnu regularizaciju za rubne čvorove. Za rubne čvorove uvedena je penalizacija za fluktuacije pomaka kratkih valnih duljina. Treća funkcija koju treba uzeti u obzir mora nestati za sve pomake krutog tijela

$$\Phi_b^2 = \{\mathbf{u}\}^t [\mathbf{L}]^t [\mathbf{L}] \{\mathbf{u}\}, \quad (8)$$

gdje je $[\mathbf{L}]$ operator koji ima utjecaj na rubu ROI-a [7].

2.2 Correlation procedura

Minimiziranje correlation reziduala (Φ_c^2), ravnotežne razlike (Φ_m^2) i rubnih fluktuacija (Φ_b^2) zahtijeva uvođenje totalnog funkcionala Φ_t^2

$$(1 + w_m + w_b) \Phi_t^2 = \tilde{\Phi}_c^2 + w_m \tilde{\Phi}_m^2 + w_b \tilde{\Phi}_b^2, \quad (9)$$

gdje su w_m i w_b težine pridodane $\tilde{\Phi}_m^2$ i $\tilde{\Phi}_b^2$, a $\tilde{\Phi}$ označava normalizirane rezidualne. Težine w_m i w_b su odabrane kao

$$w_m = (2\pi |\mathbf{k}| l_m)^4, \quad w_b = (2\pi |\mathbf{k}| l_b)^4, \quad (10)$$

gdje su l_m i l_b regularizacijske dužine za Φ_m^2 i Φ_b^2 . U slučaju da se zada viša vrijednost regularizacijske dužine l_m stavlja se veća težina na funkcional $\tilde{\Phi}_m^2$, te stoga ravnotežni reziduali moraju dosegnuti veću razinu. Isto vrijedi i za zadavanje regularizacijske dužine l_b za rubne rezidualne. U RT3-Correli algoritmu koriste se trokutasti elementi (T3) sa linearnom interpolacijom pomaka.

3 PRIMJERI I REZULTATI REGULARIZACIJSKE DIC METODE


U ovom dijelu rada prikazana su dva primjera u kojima je korišten R-DIC. Prvi slučaj će biti umjetno deformiran, dok će u drugom biti razmatran stvarni test u kojem će se analizirati prirodna tekstura nodularnog lijeva prilikom izvođenja biaxialnog testa. U oba slučaja rezultati će biti uspoređeni sa "local" i "global" DIC algoritmom.

3.1 Umjetno deformiran test


Na primjeru umjetno deformiranog testa analizirana je slika s umjetnom teksturom koja je napravljena tako da se prvo nanese bijela boja, a nakon toga crnom bojom stohastički se nanese crne točkice. Ovo je uobičajena metoda za stvaranje rastera pogodnog za primjenu DIC metode. Na ovom primjeru veličina slike je 531x531 piksel sa 8-bitnom digitalizacijom. Iz referentne slike (Sl. 1) linearnom interpolacijom sive skale generirana je deformirana slika bez šumova koji su neizbježni prilikom registriranja slike u stvarnom testu. Generirano polje pomaka deformirane slike je sinusna funkcija (Sl. 2 (a) i (b))

$$u_x(x, y) = 2 \sin(2\pi x / n_x), \quad u_y(x, y) = 2 \sin(2\pi x / n_y), \quad (11)$$

gdje su n_x x n_y broj piksela ROI-a. Deformiranje slike sinusnom funkcijom zanimljiv je slučaj zato što odgovara osnovnoj analizi optičkih sustava [2].

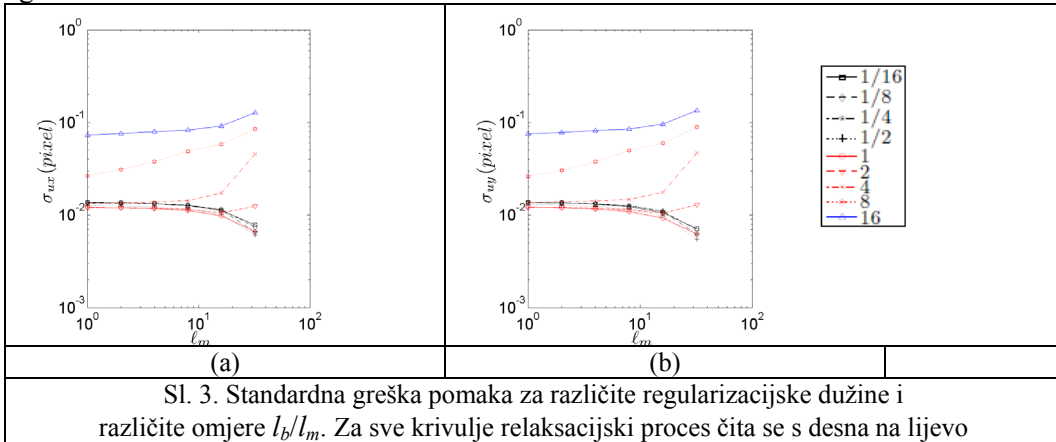


Sl. 1. Referentna slika



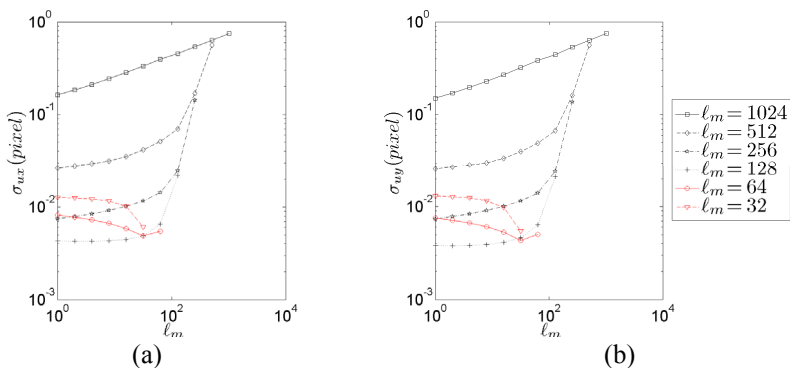
Sl. 2 Generirana polja pomaka u x i y smjeru

Na ovom primjeru testirani su omjeri l_b/l_m . Svrha određivanja omjera l_b/l_m je u tome da omjer u daljnjim analizama na stvarnim testovima bude konstantan. Za početnu vrijednost odabrano je $l_m=32$ piksela pri čemu se on inkrementalno smanjivao (relaksirao) za 2 puta sve do vrijednosti $l_m=1$ pix. Iz dijagrama Sl. 3 (a) i (b) vidljivo je da je za omjere od 1 do 1/16 standardna greška između mjerenog i generiranog polja pomaka približno jednaka te je zbog toga odabran omjer od 1/2 koji daje najmanju grešku.



Sl. 3. Standardna greška pomaka za različite regularizacijske dužine i različite omjere l_b/l_m . Za sve krivulje relaksacijski proces čita se s desna na lijevo


Sl. 4 pokazuje razliku standardne devijacije između mjerenog i generiranog polja pomaka za različite slučajeve inicijalne regularizacijske dužine unutrašnjih čvorova. Kao i u prethodnom slučaju l_m se smanjuje za 2 puta u svakom inkrementu. Standardna greška pomaka virtualno je jednaka za dvije komponente pomaka (osim za velike regularizacijske dužine) iako je korištena nestrukturirana mreža. Zbog toga što T3 mreža nije regularna nisu uočene nikakve greške. Primjenjujući različite početne regularizacijske dužine vidljivi su različiti trendovi. Prvo, za jako velike inicijalne $l_m > n_x, n_y$ standardna greška je jako visoka. Ovaj efekt uzrokovan je interpolacijskim greškama zato što onemogućuju bilježenje male fluktuacije pomaka. Kada se relaksira l_m vidljiva je manja ali ipak značajna greška. Za inicijalno male regularizacijske dužine standardna greška ostaje mala ali relaksacija uzrokuje malo povećanje greške. Kod odabrane inicijalne regularizacijske dužine $l_m=128$ piksela uočena je najmanja greška. Važno je napomenuti da je za inicijalne $l_m < 128$ piksela greška manja od 10^{-2} .



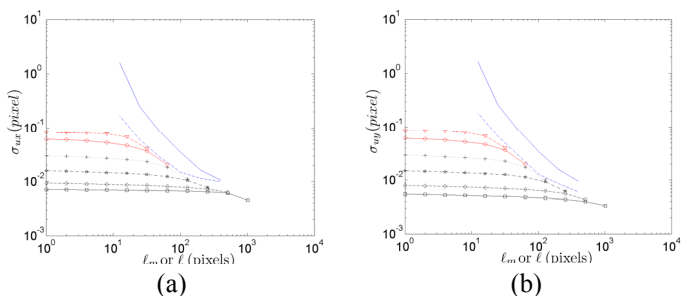
Sl. 4. Promjena standardne greške pomaka za različite regularizacijske dužine i različite inicijalne l_m naznačene u legendi

3.2 Analiza prirodne teksture

Par slika (Sl. 5) analiziran u ovom primjeru odgovara slikama zabilježenim uzastopno kada je uzorak već pričvršćen na ispitni uređaj sa silom $F=0$ N. Križna epruveta izrađena iz nodularnog lijeva opterećena je equi-biaksialno duž dva okomita pravca. Centar ispitnog uzorka promatran je na meso razini (definicija slike: 1024x1280 piksela sa 12-bitnom digitalizacijom) gdje se koristila prirodna tekstura materijala. Na slici 5 vidljivo je da je tekstura siromašna s obzirom na prethodno analizirani slučaj (Sl. 1). Ova analiza je napravljena kako bi se evaluirala rezolucija R-DIC metode.



Sl. 5 Referentna slika prirodne teksture nodularnog lijeva



Sl. 6. Promjena standardne greške pomaka za različite regularizacijske dužine i različite inicijalne l_m naznačene u legendi na slici 4

Na slici 6 prikazana je standardna rezolucija pomaka za dvije komponente pomaka. Iz dijagrama je vidljivo da što je veća regularizacijska dužina manja je rezolucija pomaka. Važno je napomenuti da je za dobivanje rezultata na slici 6 bilo potrebno izvršiti 51 analizu. Rezultati rezolucije pomaka dobiveni regularizacijom uspoređeni su s lokalnim i globalnim DIC pristupom. Vidljivo je da je trend kod ova dva pristupa dugačiji nego kod regulariziranog. Kod analize ovako siromašne teksture vidljiva je značajna razlika između lokalnog i globalnog pristupa. Značajna dodatna razlika koju je napravila regularizacijska tehnika uvedena u ovom radu, uspjela je iskućivo zato što su filtrirane sve nemehaničke fluktuacije zabilježene na slikama.

4 ZAKLJUČAK

U ovom radu prikazano je kako uvođenje mehanički temeljene regularizacije u DIC algoritam zasnovan na formulaciji konačnih elemenata značajno smanjuje razinu nesigurnosti umjetno neuniformno generiranog polja pomaka. Primjena iste metodologije na realnom eksperimentu pokazuje da se i slike sa siromašnom teksturom mogu uspješno analizirati DIC tehnikom. U prikazanom istraživanju diskretizacija temeljena na nestrukturnoj mreži od trokutastih elemenata (tj. T3-DIC) korištena je prilikom DIC analize. Primjena trokutastih elemenata manje je zahtijevna od DIC metode na razini piksela ("Pixel-scale" DIC; P-DIC). Usprkos tome vjeruje se da su rezultati dobiveni ovom metodom generički i da bi se u sljedećim istraživanjima mogli primijeniti na P-DIC.

Literatura:

- [1] Bergonnier, S., Hild, F., Roux, S., "Digital image correlation used for mechanical tests on crimped glass wool samples", *J. Strain Analysis*, 40, 2, 2005, str. 185-197.
- [2] Bornert, M., Brémand, F., Doumalin, P., Dupré, J-C., Fazzini, M., Grédiac, M., Hild, F., Mistou, S., Molimard, J., Orteu, J-J., Robert, L., Surrel, Y., Vacher, P., Wattrisse, B., "Assessment of Digital Image Correlation measurement errors: Methodology and results", *Exp. Mech.*, 49, 3, 2009, str. 353-370.
- [3] Sutton, MA., Wolters, WJ., Peters, WH., Ranson, WF., McNeill, SR., "Determination of Displacements Using an Improved Digital Correlation Method", *Im. Vis. Comp.*, 1, 3, 1983, str. 133-139.
- [4] Sun, Y., Pang, J., Wong, C., Su, F., "Finite-element formulation for a digital image correlation method", *Appl. Optics*, 44, 34, 2005, str. 7357-7363.
- [5] Rupil, J., Vincent, L., Hild, F., Roux, S., "Probabilistic modeling of mesocrack initiations in 304L stainless steel", *Int. J. Multiscale Comput. Eng.*, 9, 4, 2011, 445-458.
- [6] Réthoré, J., Roux, S., Hild, F., "An extended and integrated digital image correlation technique applied to the analysis fractured samples", *Eur. J. Comput. Mech.*, 18, 2009, str. 285-306.
- [7] Leclerc, H., Périé, J-N., Roux, S., Hild, F., "Voxel-scale digital volume correlation", *Exp. Mech.*, 51, 4, 2011, str. 479-490.

Autori:

Zvonimir Tomičević, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zavod za tehničku mehaniku, Ivana Lučića 5, tel. 01/ 6168 533, fax 01/ 6168 250, e-mail: zvonimir.tomicevic@fsb.hr

Frane Pamuković, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zavod za tehničku mehaniku, Ivana Lučića 5, tel. 01/ 6168 447, fax 01/ 6168 250, e-mail: frane.pamukovic@fsb.hr

Martin Surjak, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zavod za tehničku mehaniku, Ivana Lučića 5, tel. 01/ 6168 445, fax 01/ 6168 250, e-mail: martin.surjak@fsb.hr

Janoš Kodvanj, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zavod za tehničku mehaniku, Ivana Lučića 5, tel. 01/ 6168 425, fax 01/ 6168 250, e-mail: janoš.kodvanj@fsb.hr